

# Apprentissage Automatique I MATH60629

Les fondements de l'apprentissage automatique – **Sommaire**  
– Semaine #2

# Un problème d'apprentissage automatique

Les trois ingrédients d'un problème de ML :

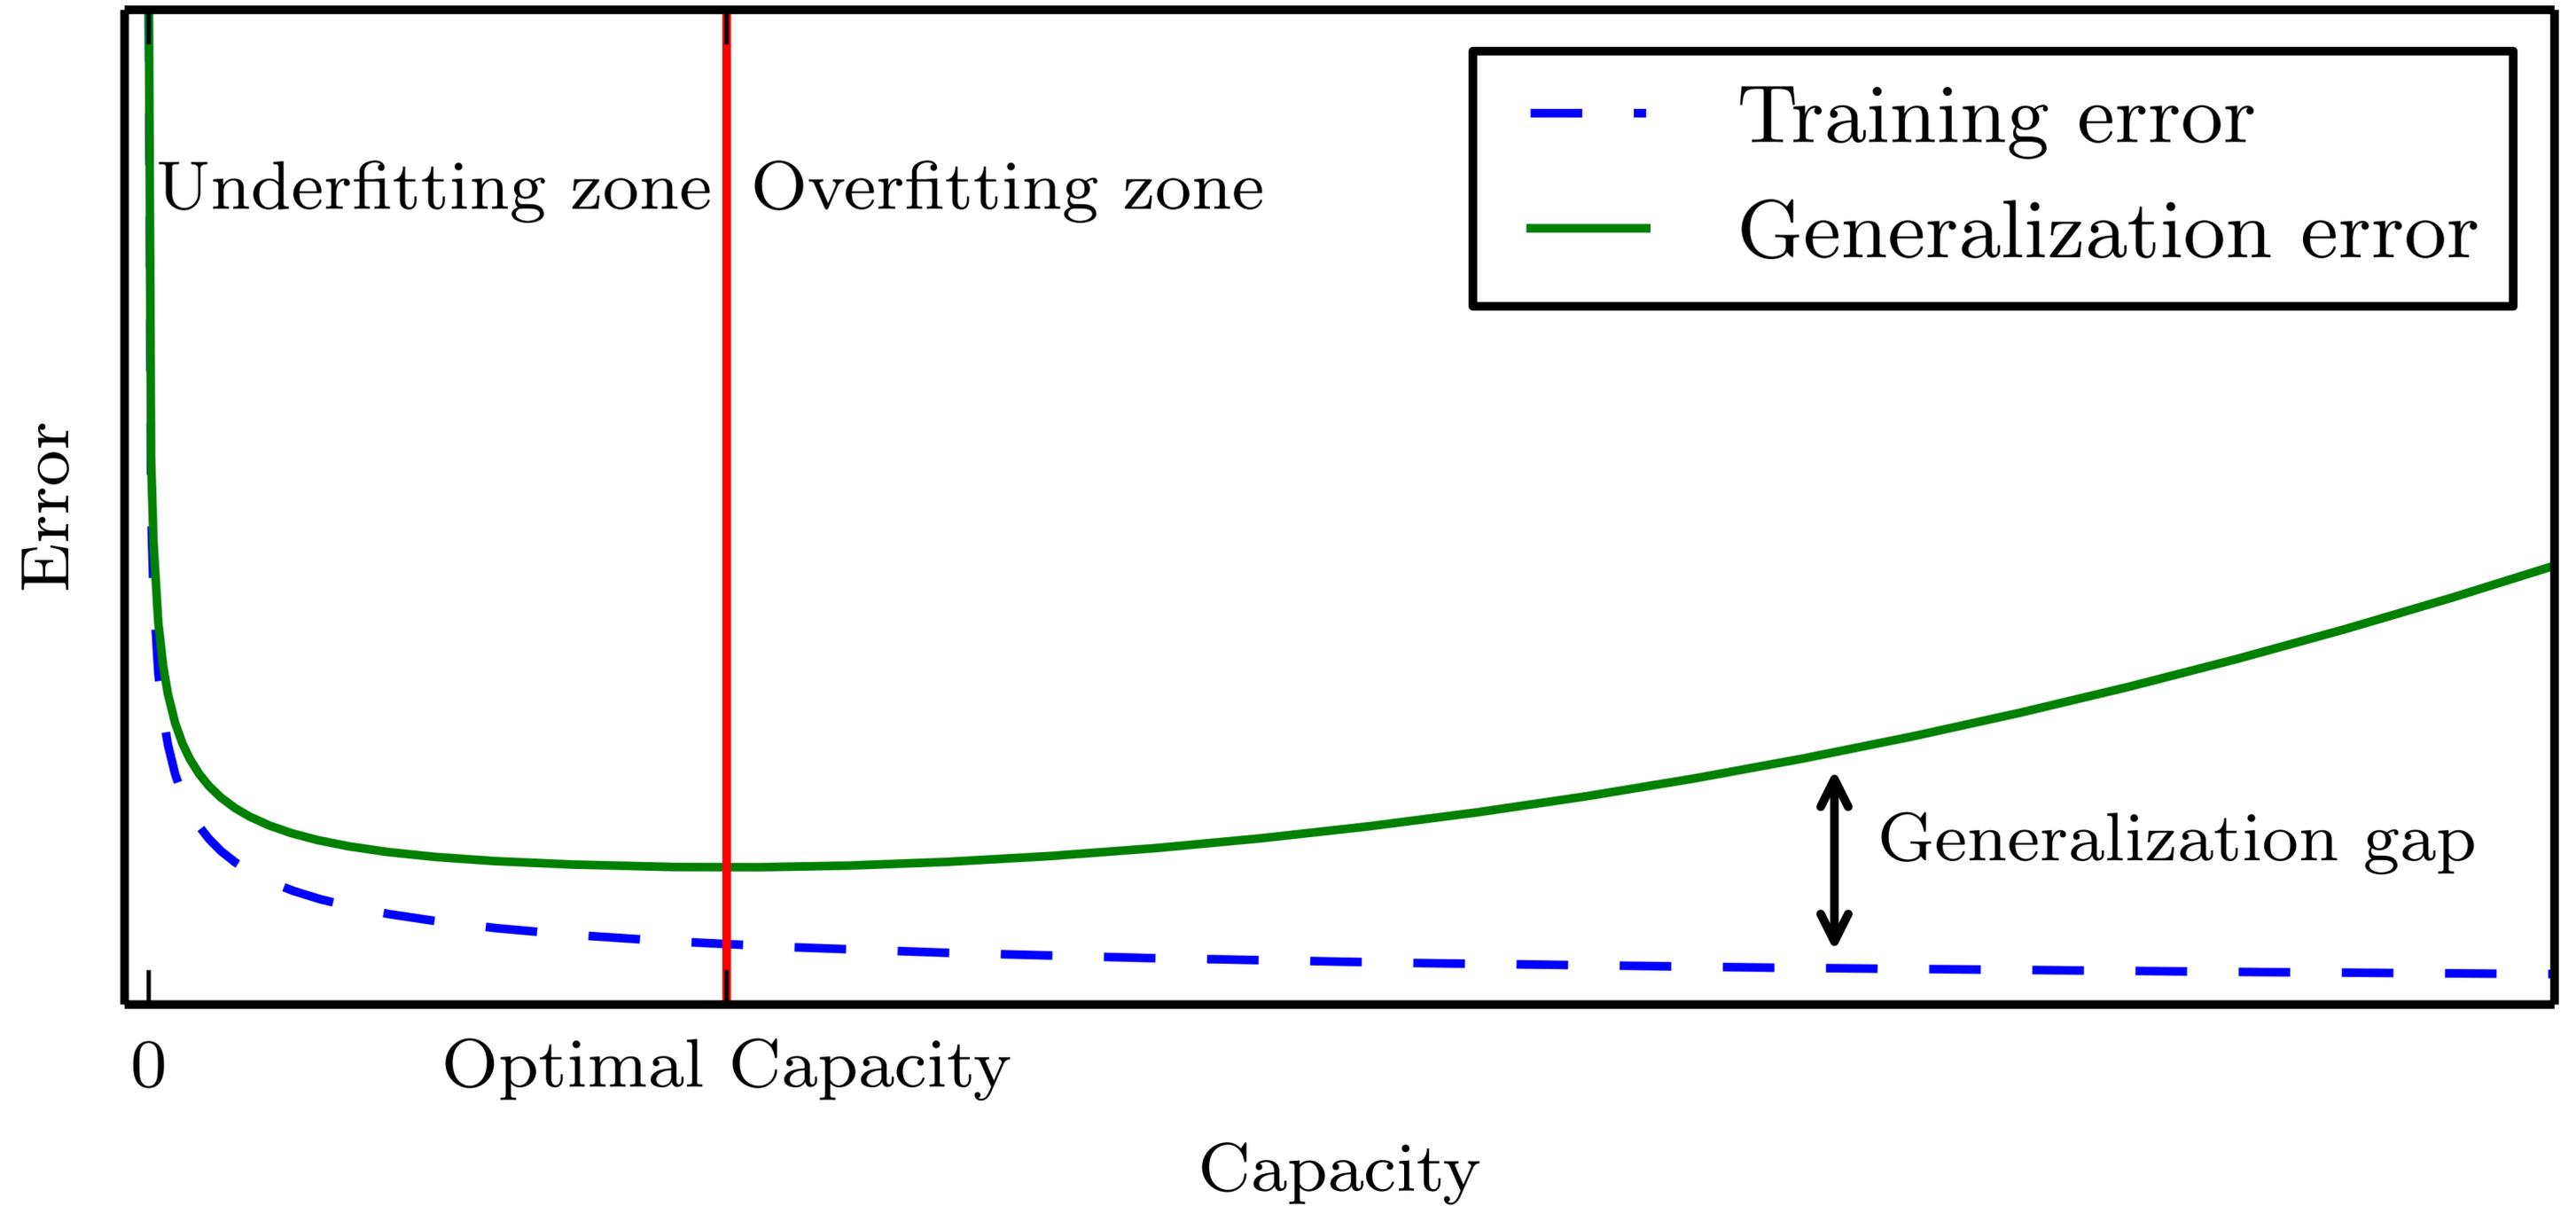
1. **Tâche.** Quel est le problème à résoudre?
  - **Modèle.** Comment paramétrer la solution.
2. **Performance.** Le modèle est-il bon?
3. **Expérience.** À quel type de données avez-vous accès?

# Les types d'expériences

- A. **Supervisé  $\{(x,y)\}$ .** P. ex., régression, classification.  $f: X \rightarrow Y$
- B. **Non supervisé  $\{(x)\}$ .** P. ex., regroupement, réduction de la dimension, estimation de la densité.
- C. **Par renforcement.** Un agent pose des actions dans un environnement.

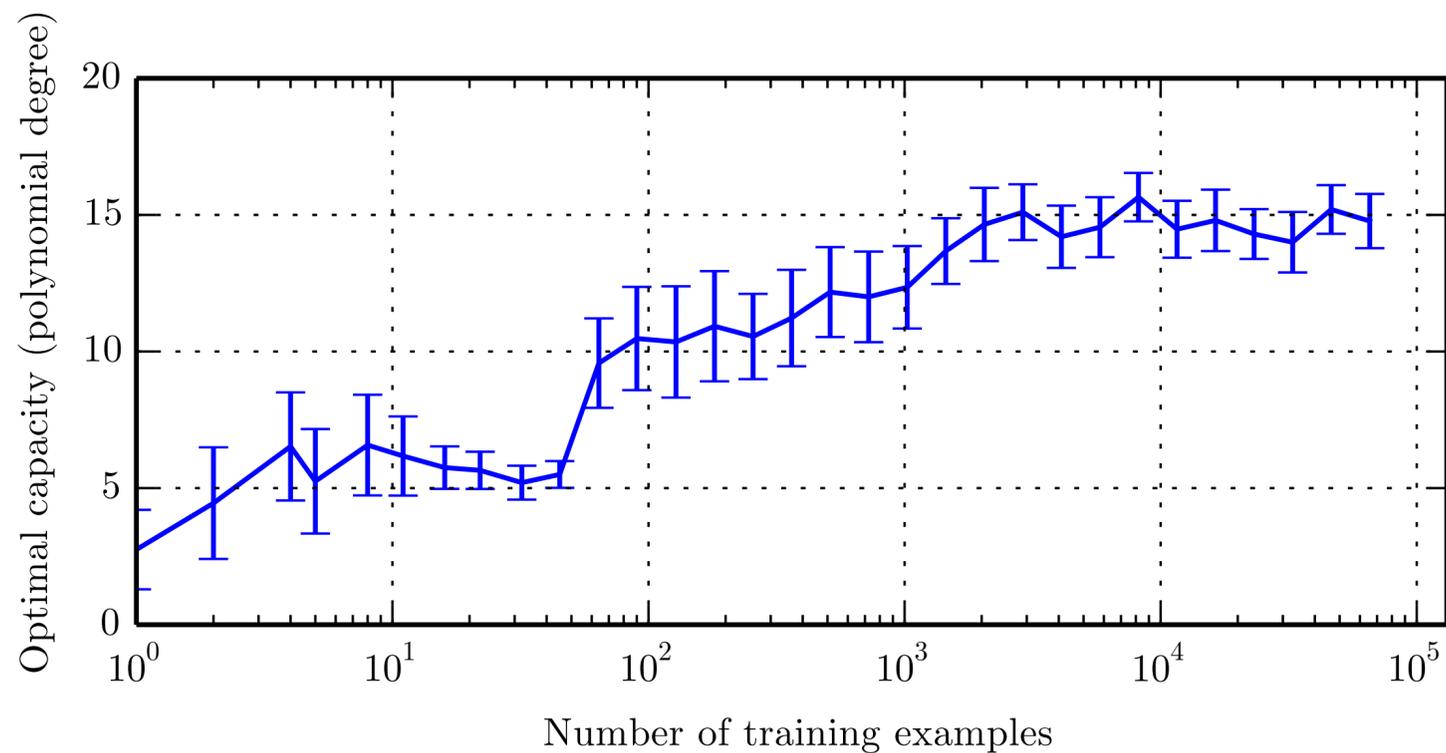
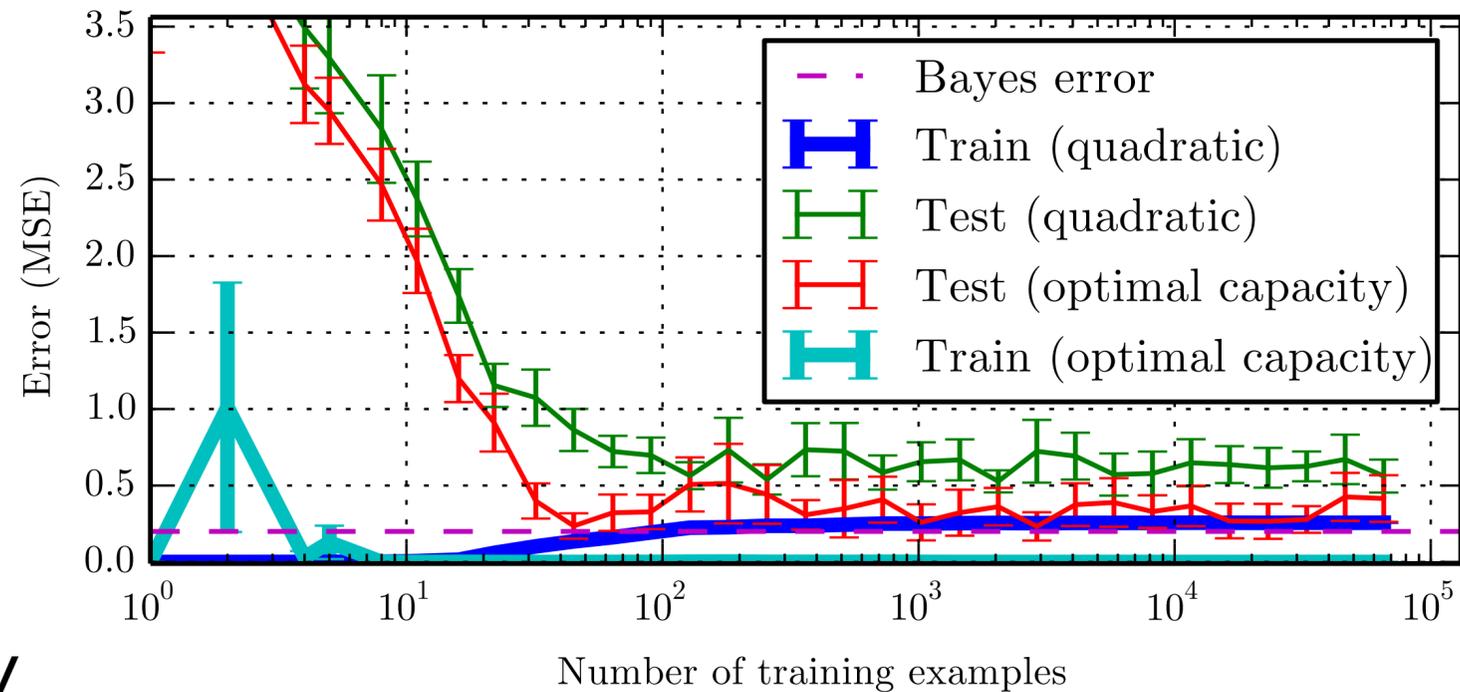
# Évaluation d'un modèle

- On nous donne:
  - Une mesure de la performance
  - Un ensemble d'entraînement
  - Un modèle
- On peut calculer:
  - L'erreur d'entraînement: on l'utilise pour apprendre.
  - L'erreur d'entraînement **ne peut pas** être utilisée pour évaluer votre modèle
    - Vous devez utiliser un ensemble de données séparé (par exemple un ensemble de validation)



Synthetic data is generated using a degree 5 polynomial  $y = w_5x^5 + w_4x^4 + w_3x^3 + w_2x^2 + w_1x^1$

Training set size also plays an important role in a model's capacity to generalize



# Regularisation

- C'est une façon de limiter la capacité d'un modèle
- $\text{Loss} := \text{MSE}^{\text{train}} + \lambda \mathbf{w}^T \mathbf{w}$

# Ensemble de Validation

- Comment choisir le bon modèle ou les bons hyperparamètres (p. ex.  $\lambda$ )?

- En utilisant un ensemble de validation

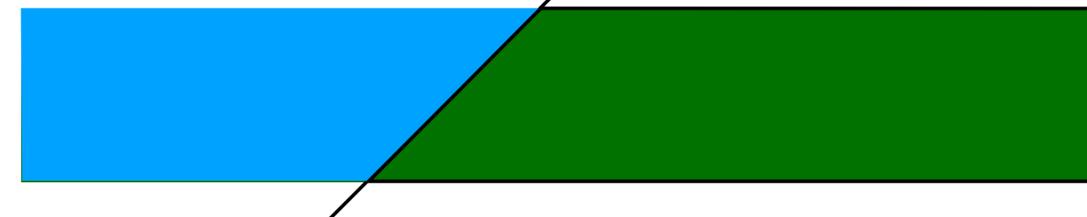
- Diviser les données en deux:

1. Ensemble d'entraînement

2. Ensemble de validation

**Train**

**Validation**

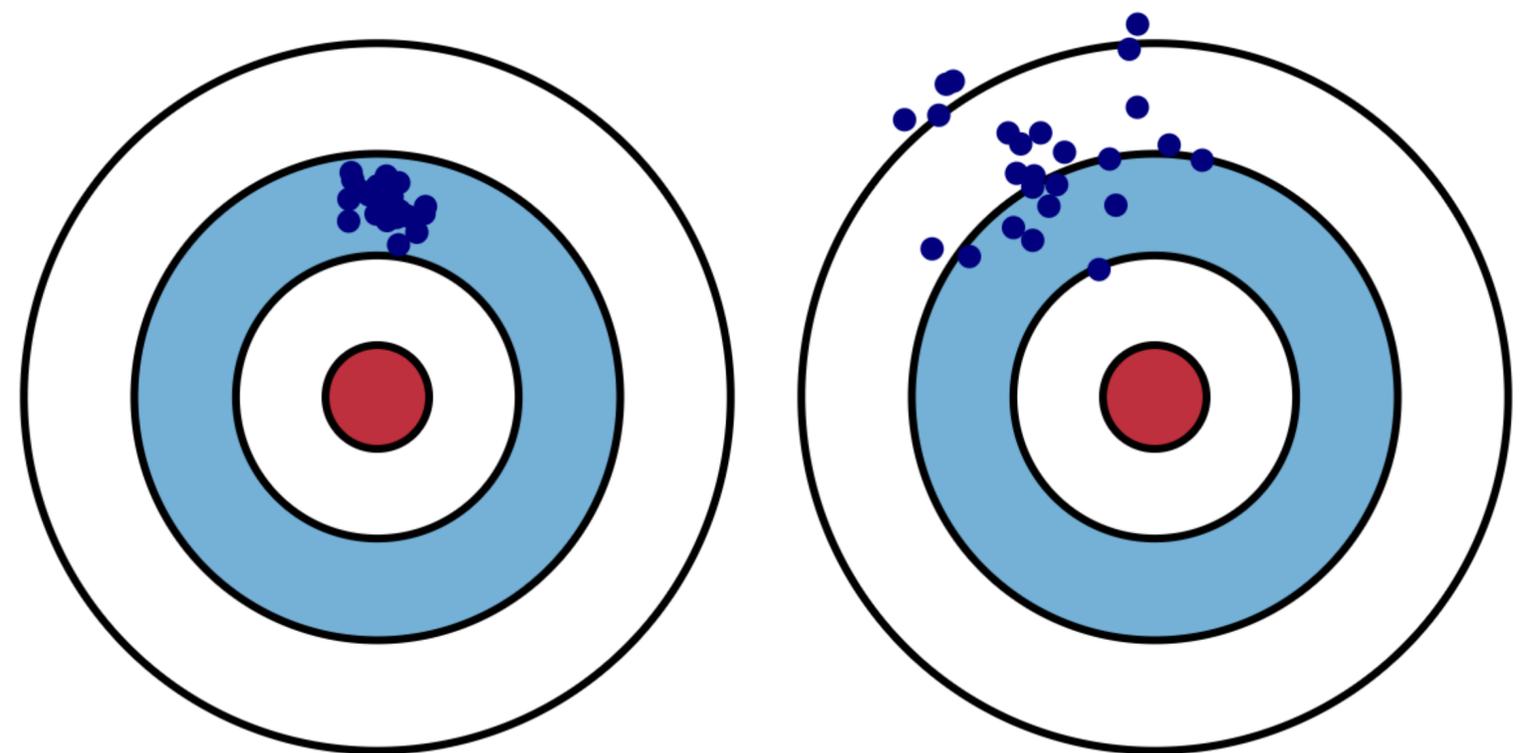
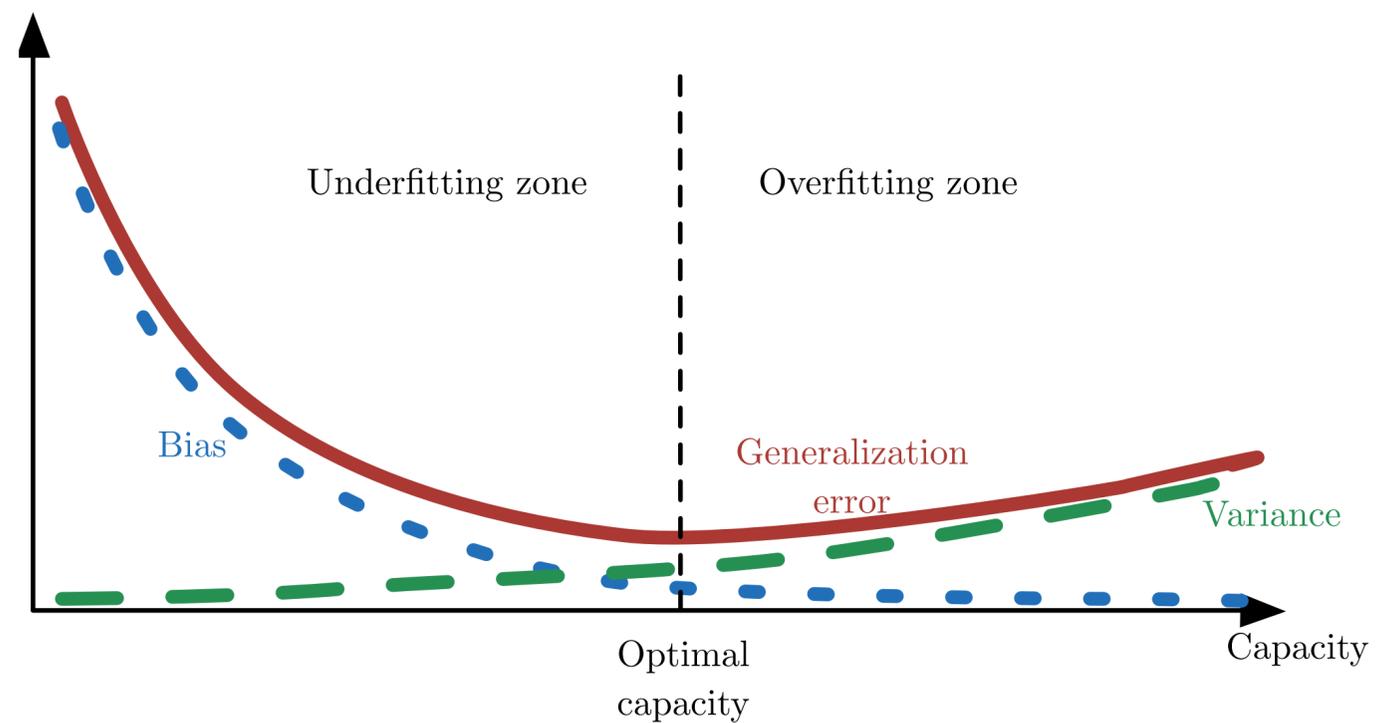
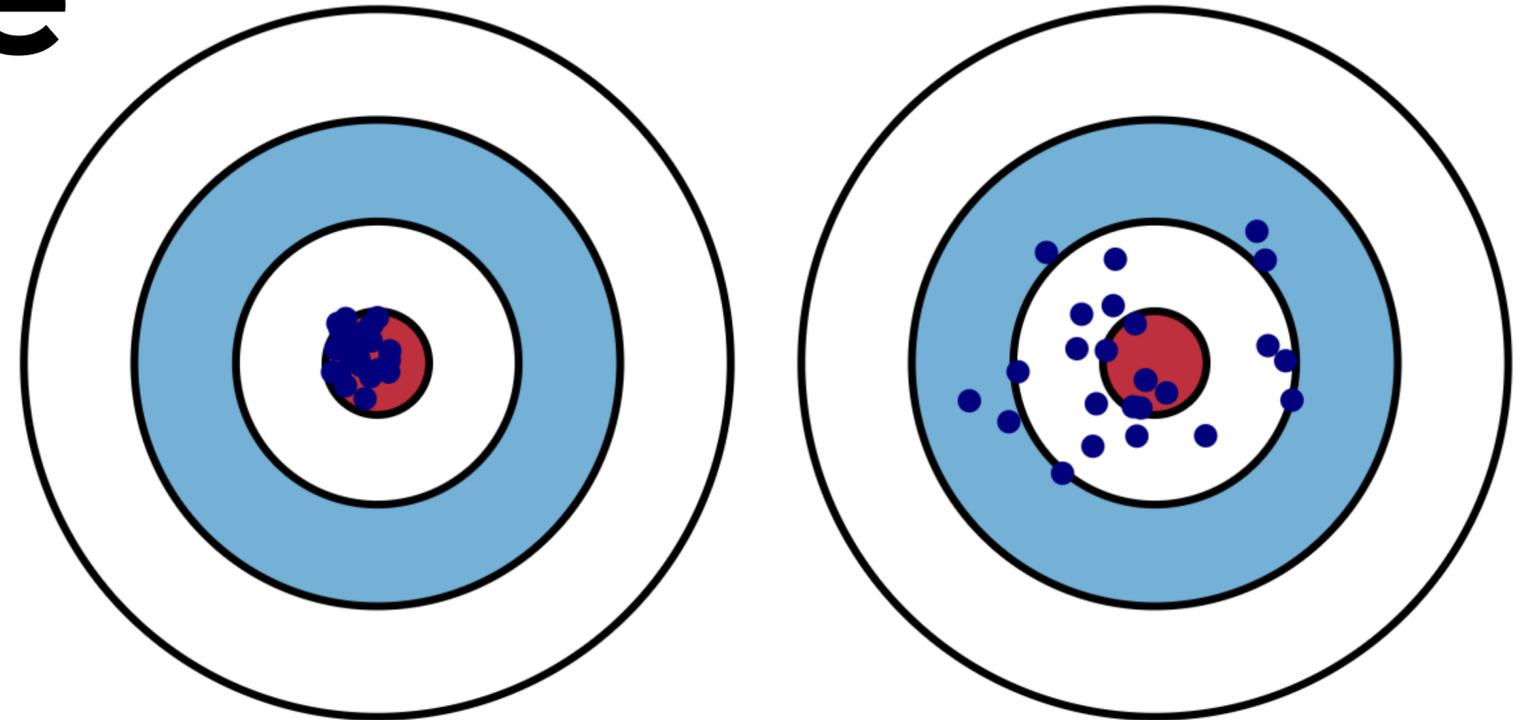


- C'est un proxy pour l'ensemble de test

- Entraînez différents modèles ou hyperparamètres sur l'ensemble d'entraînement
- Choisissez le meilleur modèle selon sa performance sur l'ensemble de validation

# Biais / Variance

- Le but est d'atteindre le centre de la cible (en rouge)
- Chaque point bleu représente la "performance" d'un modèle sur un ensemble de données venant d'une distribution fixe



# Biais / Variance

- Le but est d'atteindre le centre de la cible (en rouge)
- Chaque point bleu représente la "performance" d'un modèle sur un ensemble de données venant d'une distribution fixe

Low Bias

Low Variance

High Variance

